

SVEUČILIŠTE U ZAGREBU  
GRAFIČKI FAKULTET

**ZAVRŠNI RAD**

Nikolina Pajić



Sveučilište u Zagrebu  
Grafčki fakultet

Smjer: Tehničko - tehnološki

# ZAVRŠNI RAD

## Objektivne mjere za kvalitetu slike

Mentor:

doc. dr. sc. Ante Poljičak

Student:

Nikolina Pajić

## SAŽETAK

Objektivne mjere za kvalitetu slike se koriste za usporedbu stupnja degradacije koju metoda obrade slikovne informacije unosi u sliku. Dvije najraširenije i najpopularnije objektivne mjere su *Peak Signal to Noise Ratio* (PSNR) i *Structural similarity index* (SSIM). Cilj eksperimentalnog dijela rada je ustanoviti koje su prednosti i mane navedenih mjera i na kojim slikama bi ih trebalo koristiti. Eksperiment će se provesti na testnoj bazi slika koje će se biti izložene standardnih metodama manipulacije slike kao što su JPEG kompresija, Gaussov filtar, dodavanje šuma te geometrijske transformacije kao što su rotacija i zrcaljenje.

Dokazali smo kako oba dvije mjere su ovisne jedna od drugoj. Rezultati jedne mjere mogu se povezati s drugom. Također, SSIM zbog svojih parametara koje koristi prilikom računanja je realniji od PSNR. PSNR je slabija jer MSE koji se računa kako bi se dobila konačna ocjena kvalitete je isti za svaku sliku.

Ključne riječi: objektivne metode, kvaliteta slika, PSNR, SSIM

## SADRŽAJ

<b>1. UVOD .....</b>	<b>5</b>
<b>2. TEORIJSKI DIO.....</b>	<b>7</b>
2.1    METODE ZA MJERENJE KVALITETE SLIKE.....	7
2.1.1    Subjektivne metode.....	7
2.1.2    Objektivne metode .....	9
2.2    OBJEKTIVNE METODE ZA ODREĐIVANJE KVALITETE SLIKE .....	12
2.2.1    PSNR - <i>Peak Signal to Noise Ratio Structural</i> .....	13
2.2.2    SSIM - <i>Structural Similarity Index</i> .....	15
2.2.3    Prednosti i mane PSNR i SSIM .....	18
2.3    MANIPULACIJE NA SLIKAMA.....	18
2.3.1    JPEG kompresija.....	18
2.3.2    Šumovi .....	19
2.3.3    Gaussov filter .....	20
2.3.4    Geometrijske transformacije .....	21
<b>3. EKSPERIMENTALNI DIO .....</b>	<b>23</b>
3.1.    Postupak izvođenja eksperimentalnog dijela .....	23
3.2.    Rezultati mjerenja i rasprava.....	26
3.3.    Usporedba PSNR i SSIM rezultata .....	27
<b>4. ZAKLJUČAK.....</b>	<b>29</b>
<b>5. LITERATURA .....</b>	<b>30</b>

## 1. UVOD

U oku središnja točka u šarenici odgovorna je za sve što vidimo. Na ljudsko oko utječe mnogo faktora kao što su godišnja doba, svjetlin ili klimatski uvjeti. Zbog toga promatrač ne može dati točnu objektivnu ocjenu za vizualni sadržaj koji promatra.

Razvojem tehnologije, digitalizacija slika je sve veća. Slike se koriste sve češće kao izvor međusobne komunikacije i razmijene informacija. Takvo moderno društvo, koje svakim danom vizualni sadržaj pohranjuje i razmijenjuje gubi percepciju kvalitete negod sadržaja naspram originala.

Kako bismo mogli dati prave vrijednosti i razlike između originala i vizualnog sadržaja na koji ćemo djelovati različitim manipulacijama kao što su JPEG kompresija, dodavanje šumova, Gaussovi filteri i geometrijske transformacije, matematičkim obradama ćemo doći do realnih rezultata koji će pokazati prave izmjene na vizualnom sadržaju.

Općenito, mjere se mogu podijeliti na subjektivne i objektivne mjere kvalitete slike, pri čemu ocijene kod subjektivne mjere daju promatrači, dok je kod objektivnih mjera rezultat mjerenja dobiven mjernim instrumentima ili proučavanjem uz upotrebu matematičkih operacija i modela. Cilj svake objektivne mjere je postići što veći stupanj sličnosti s rezultatima subjektivnih mjerenja, neovisno o vrsti izobličenja u slici i što veća brzina proračunavanja za primjene u stvarnom vremenu.

U nastavku će se dati prikaz objektivnih postupaka ocijene kvalitete vizualnog sadržaja, kao i usporedba dvije najzastupniji objektivne metode, a to su PSNR (*Peak Signal to Noise Ratio*) i SSIM (*Structural Similarity Index*).

PSNR (*Peak Signal to Noise Ratio*) je metoda koja kao krajnji rezultat prikazuje kvalitetu ispitivan slike u odnosu na original, tj. prikazuje stupanj izobličenja ispitanog sadržaja na temelju usporedbe s originalom. Rezultat je ustvari logaritamski omjer između najveće moguće snage signala i snage šuma[4].

SSIM (*Structural Similarity Index*) je metoda koja prilikom uspoređivanja uzima u obzir strukturalne sličnosti. Ona je poznata po visokoj korelaciji sa subjektivnim

rezultatima ocjene kvalitete slikovnog sadržaja. Ova mjera uzima u obzir kontrast, svjetlno i strukturu te povezivanjem te tri stavke daje nam konačnu ocjenu, SSIM indeks koji nam daje informacije o kvaliteti slike[4].

PSNR mjera se koristi u eksperimentima gdje je brzina izvođenja bitna, ali ova mjera daje lošije rezultate u odnosu na druge objektivne mjere[1]. Da li je taj eksperiment zadovoljio uvijete i da li će se pokazati da je SSIM ipak lošija objektivna metoda za određivanje slika, prikazati će se u daljnjem eksperimentalnom dijelu.

## **2. TEORIJSKI DIO**

### **2.1 METODE ZA MJERENJE KVALITETE SLIKE**

Dojam o vizualnom sadržaju uvelike ovisi o ljudskoj percepciji te njihovom sustavu za pohranu, obradu i prijenos vizualnih sadržaja. Mnogi znanstvenici su do sada pokušali objasniti promjene kvalitete izmjenom sadržaja unutar istih. Objektivne mjere su postupci procjene tih promjena. Uz objektivne mjere postoji i njihova suprotnost, subjektivne mjere, koje se oslanjaju na ljudski vizualni sustav tj. oslanjaju se na vizualni sustav samog promatrača. Dok se zaključak u objektivnom postupku izražava kao koeficijent korelacije, subjektivna metoda se izražava kao skup ocjena određene grupe.

#### **2.1.1 Subjektivne metode**

Kao što smo rekli, subjektivni postupci oslanjaju se na vizualni sustav pojedinca odnosno grupe čije ocjene ocjenjuju neki vizualni sadržaj. Pri tome se sumiraju sve ocjene te se ukupna ocjena temelji na prosjeku tog zbroja. S obzirom da je temelj cijele ove metode vizualni dojam pojedinca, možemo reći da se cijele metoda temelji na konačnoj ocjeni vizualnog sadržaja.

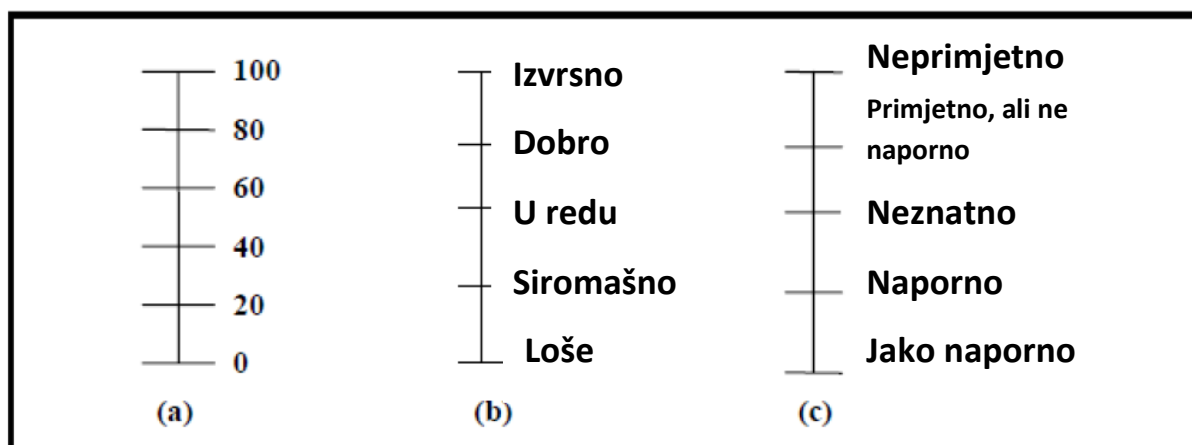
Važno je pri tome napomenuti da dobiveni rezultat nije savršeno točan pošto se radi o statističkim rezultatima koji se temelje na subjektivnosti odabranih pojedinaca. Zbog toga u ovoj metodi postoje različiti faktori o kojima rezultati mogu ovisiti, kao što su: sadržaj vizualnog podražaja koji se ispituje, raspoloženje pojedinaca, uvjeti pod kojim se vizualni sadržaj promatrao pa čak i okolina u kojoj se isti promatra.

Subjektivne metode mogu se podijeliti na :

SS (*Single Stimulus*) subjektivnu metodu

Promatraču je prikazana samo slika kojoj se određuje kvaliteta. Tim pristupom pokušavaju se simulirati uvjeti u kojima želimo pred promatrača postaviti samo komprimiranu (izmjenjenu) sliku bez da je isti bio u susretu sa originalom. Ovakva metoda za manu ima problem ne mogućnosti odvajanja slika pri promatranju u nizu. Na

temelju tog niza promatrač ocjenjuje sliku pri usporedbi sa prethodnom. Zbog toga nakon nekog vremena percepcija vizualnog podražaja se adaptira te je ne funkcionalna. Ove metode primjenjuju se u određivanju kvalitete videa, gdje nema mogućnosti za korištenje originala. [5]



**Slika 1** Ocijene promatrača a) kontinuirana skala b)skala kvaliteta c) skala poboljšanja

DS ( *Double Stimulus*) subjektivna metoda

Pred promatrača se postavlja i original i izmijenjena slika koju testiramo, pri čemu promatrač niti u jednom trenutku nije upoznat sa činjenicom koja od slika je original.

Ova metoda može imati dva načina ocjenjivanja:

1. promatrač ocjenjuje obje slike te je rezultat usporedba tih ocjena
2. promatrač bira kvalitetniju sliku od dvije ponuđene.

Ova metoda se koristi ukoliko želimo provjeriti neku od objektivnih metoda. [5]

Prema predmetu mjerenja subjektivne metode kvalitete mogu se podijeliti na:

Opće subjektivne metode

Metode koje se određuju neovisno o primjeni slika koje kontroliramo, pri čemu promatraču zadajemo pitanja kao što npr. Kolika je kvaliteta? Kolika je razlika između dvije slike. Ovu metodu još nazivamo i MOS (*Mean Opinion Score*) metodama, a srednju ocjenu kvalitete MOS ocjenom [5].



Domenska subjektivna metoda

Metoda koja određuje kvalitetu slike na osnovi upotrebljivosti iste u nekoj domeni primjene. Kvaliteta se određuje usporedbom sa originalom, pri čemu se ocjenjuje razlika u mogućnosti izvršavanja zadatka sa slikom koju ispitujemo i originalne slike [5].

### **2.1.2 Objektivne metode**

Objektivne metode možemo zvati numeričkim ili matematičkim metodama [8]. Slika se smatra signalom te se samim time stvara predodžba o kvaliteti iste. Ove metode mogu mjeriti razliku u boji, osvjetljenju i/ili kontrastu između originala i ispitivane slike.

Prilikom procesa određivanja kvalitete slike do ocjene se dolazi matematičkim postupkom unaprijed definiranim formulama, pri čemu čovjek nikako ne utječe na samu krajnju ocjenu. Utjecaj promatrača se bazira definiranim parametrima i ulaznim vrijednostima algoritma, kako bi se dobio broj kojim se prikazuje kvaliteta slike. U nekim literaturama rečeno je kako je objektivna metoda napravljena kako bi se zamijenile subjektivne metode [9]. Objektivnim metodama je zadatak da precizno i brzo, neovisno o samom sadržaju i veličini slike daju konačni rezultat. Raznim ispitivanjima se pokazalo kako je jednostavnije napraviti objektivnu metodu koja daje rezultate za određivanje kvalitete, nego napraviti metodu koja daje slične ili iste rezultate kao subjektivna metoda [10].

Prilikom određivanja kvalitete slikovnog sadržaja razlikujemo tri postupka:

#### *Full Reference (FR)*

Objektivna mjera koja dolazi do rezultata ispitivanje testne slike uz prisustvo originalne slike i tako ih uspoređuje. Problem ove metode je što ukoliko nemamo originalnu sliku nemamo dovoljno podataka kako bi se mogla izračunati kvaliteta slike. Metoda poznata po svojoj jednostavnosti i popularnosti, a spada u ove postupke je PSNR (*Peak Signal to Noise Ratio*) metoda. Metoda radi na principu usporedbe originala s transformiranom slikom. PSNR ocjenjivanje kvalitete jedna je od metoda ocjenjivanja koja pri ocjenjivanju različitih kompresija daje određene podatke koje nama pomažu pri odabiru najprikladnije metode kompresije pri pohrani vizuala. Što je veća vrijednost PSNR-a to

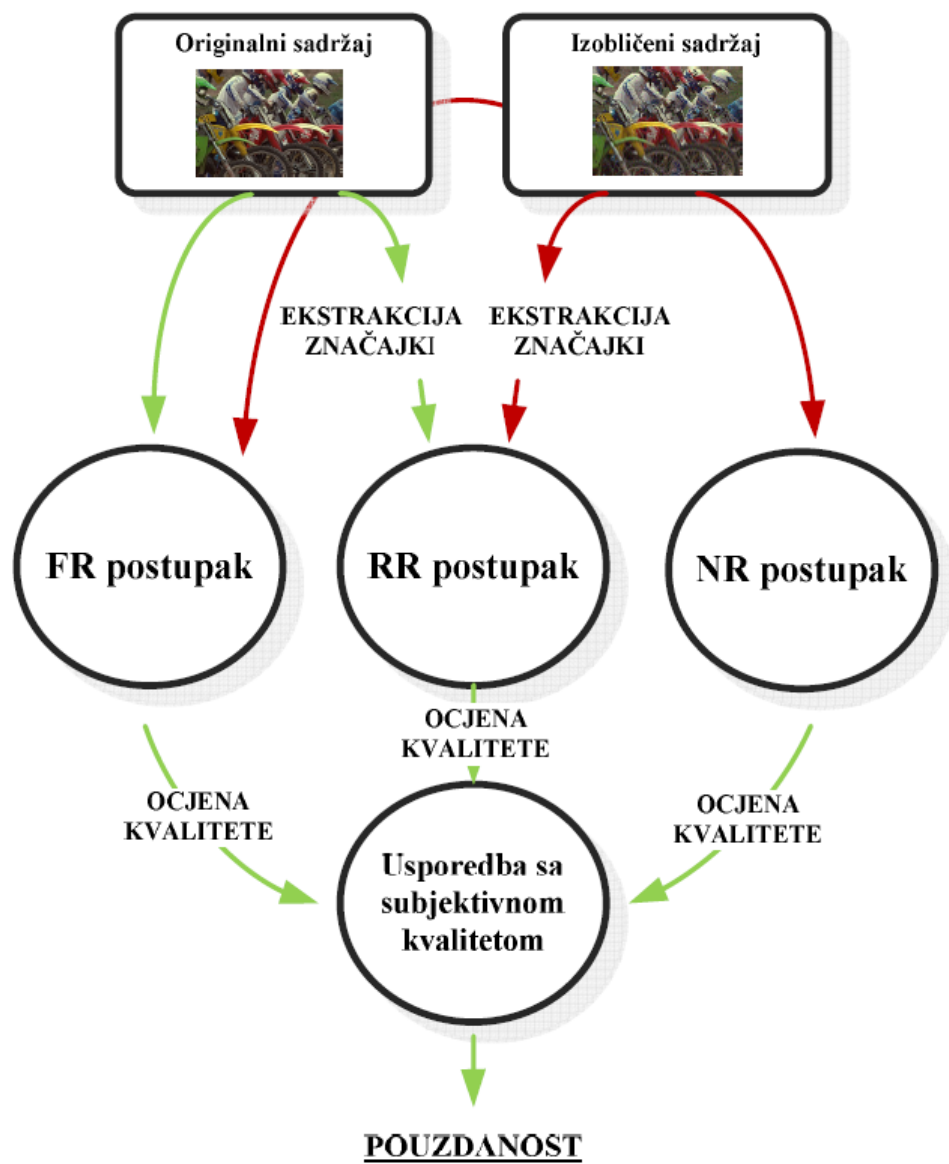
je kvalitetnije rekonstrukcija. Maksimalna vrijednost mu je 100 decibela što drugim riječima predstavlja originalnu sliku. Druga metoda koja pripada ovim postupcima je SSIM ( *Structural Similarity Index*) metoda. Ova metoda pokušava iskoristiti ljudski vizalni sustav koji je osjetljiv na razna izobličenja. Ova metoda je usko povezana uz kontrast i svjetlinu koje nastaju unutar ispitivane slike. Rezultati u ovoj metodi su dani između 0 i 1, 0 je pokazatelj da nema nikakve sličnosti između originala i ispitivane slike, dok 1 pokazuje da su slike identične.

#### *Reduced Reference (RR)*

Objektivan metoda koja je utemeljena na usporedbi i izvlačenju bitnih stavki originala i transformiranog sadržaja. Do ocijene se dolazi usporedbom statističkih podataka koji su dobiveni iz stavki originala i transformiranog sadržaja.

#### *No Reference(NR)*

Objektivna metoda koja vrednuje izobličenja u ispitanom sadržaju bez upotrebe originalnog sadržaja. Do ocijene kvalitete transformiranog sadržaja se dolazi na stavkama tog istog bez ikakve prisutnosti originala.



Slika 2 Postupci objektivnih mjerenja kvalitete vizualnog sadržaja[4]

## 2.2 OBJEKTIVNE METODE ZA ODREĐIVANJE KVALITETE SLIKE

Kvalitetu slike možemo odrediti korištenjem sljedećih šest postupaka:

- MSE (*Mean Squared Error*),
- PSNR (*Peak Signal-to-Noise Ratio*),
- SSIM (*Structural Similarity*),
- MSSIM (*Multiscale SSIM*),
- VIF (*Visual Information Fidelity*),
- VSNR (*Visual Signal-to-Noise Ratio*).

MSSIM mjera se bazira na SSIM mjeri koristeći kontrast i strukturu te se one računaju po različitim frekvencijskim ljestvicama, a svjetlina se računa po zadnjoj najnižoj ljestvici. MSSIM je mjera koja se računa po već unaprijed napravljenim koeficijentima koji su na tim ljestvicama. Ova metoda je dobra što se rezultati eksperimenta mogu podešavati. Podešavanja se rade na način da se podešava udaljenost promatrača od ispitivanih slika. Rezultati su prikazani kao 1 i 0. 1 je pokazatelj da su slike identične, dok 0 pokazuje različitosti između slika[1].

VIF mjera uzima informacije koje su podijeljene između referentne i ispitivane slike u odnosu na informaciju koja se nalazi u samoj referentnoj slici. Tu se koriste modeli prirodne scene NSS(*Natural Scene Statistic*) zajedno s modelom ispitivane slike i model ljudskog vizualnog sustava HVS(*Human Visual System*). Rezultati su od 0 do 1. 0 je pokazatelj da nema sličnosti, dok 1 pokazuje da su slike identične[1].

VSNR je mjera koja u dva koraka računa izobličenja. U prvom se određuju izobličenja prirodnih slika putem *wavelet* modela vizualnog maskiranja. Ukoliko je izobličenje ispod praga vidljivosti smatra se da je slika savršena( $VSNR = \infty$ ). Ako je suprotno, odnosno ako je izobličenje iznad praga, tada se u drugom koraku računaju vizualna svojstva preko više ljestvica. Niže ljestvice se koriste za kontrast, srednje ljestvice su za efekt boljeg uočavanja lokalnog maksimuma unutar slike. Krajnji rezultat se dobija preko suma udaljenosti navedenih svojstva. Veći VSNR znači da je ispitivana slika

sličnija originalnoj. Veći VSNR označava ustvari broj koji pokazuje da slika ima najmanje pogreška[1].

### 2.2.1 PSNR - *Peak Signal to Noise Ratio Structural*

*Peak signal-to-noise ratio*, tj. PSNR je omjer između maksimalne moguće snage signala i snage šuma koji utječu na kvalitetu vizualnog sadržaja [3]. PSNR je inženjerski izraz izražen u logaritamskoj ljestvici decibela zato što mnogi signali imaju širok dinamički raspon.

Ova metoda se najčešće koristi kao mjera kvalitete rekonstrukcije *codeca* za sažimanje. Na primjeru toga signal je originalni podatak, a šum je pogreška do koje je došlo. Pri uspoređivanju *codeca*, PSNR je aproksimacija ljudske percepcije rekonstrukcijske kvalitete. Veći PSNR generalno ukazuje da je kvaliteta rekonstrukcije veća. U nekim slučajevima ti rezultati ne moraju biti istiniti i nemoguće ih je očitati na taj način. Potrebno je oprezno tumačiti vrijednost PSNR, a pouzdano je točan samo pri usporedbi rezultata istog *codeca* (ili tipa *codeca*) i istog sadržaja.

PSNR je vrijednost koja predstavlja logaritamski omjer snage signala ekvivalentnog kvadratu maksimalne moguće vrijednosti elementa slike i snage šuma ekvivalentne iznosu srednje kvadratne pogreške MSE (*Mean Square Error*) između elemenata originalnog i izobličenog slikovnog sadržaja [4]. PSNR se definira prema:

$$\text{PSNR}_{\text{db}} = 10 \log_{10} \frac{(2^n - 1)^2}{\text{MSE}} \quad (1)$$

gdje je  $n$  broj bita korištenih za kodiranje elemenata izvorne slike dok MSE predstavlja srednju kvadratnu pogrešku između elemenata originalne  $x_{ij}$  i izoblicene slike  $x'_{ij}$ , a definira se prema sljedećoj relaciji:

$$\text{MSE} = \frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=1}^{N-1} (x_{ij} - x'_{ij})^2 \quad (2)$$


Za upotrebu 8 bitnih slika, MSN se računa kao suma kvadrata razlike između referentne i ispitivane slike :

$$\mathbf{MSE} = \frac{\sum_i \sum_j (a_{i,j} - b_{i,j})^2}{x y} \quad (3)$$

U jednadžbi su  $a_{i,j}$  i  $b_{i,j}$  vrijednosti piksela referentne i ispitivane slike na mjestu  $(i,j)$ ,  $x$  i  $y$  su visina i širina slika, te 255 maksimalna amplituda signala [1] . PSNR je logaritamski omjer između najveće moguće snage signala i snage šuma:

$$\mathbf{PSNR} = 10 \log_{10} \frac{255^2}{MSE} \quad (4)$$

Ovom metodom dolazimo jednostavno i brzo do rezultata, ali ti rezultati ne predstavljuje idealno mjerilo ocjene jer rezultati nisu dobro u suglasnosti s rezultatima dobivenih pomoću subjektivnih postupaka za kvalitetu slike. PSNR ocjena kvalitete slikovnog sadržaja ne koji smo utjecali različitim intenzitetima manipulacija daje korisne podatke na osnovu kojih se provodi odabir najprikladnije metode kompresije za pojedine sustave pohrane ili prijenosa vizualnih informacija. Veće vrijednosti PSNR-a znače kvalitetniju rekonstrukciju pri čemu maksimalna vrijednost iznosi sto decibela. Sto decibela je pokazatelj identičnost originalne, izvorne i izobličene, rekonstruirane slike [5]. Nepouzdanost i nevjerodostojnost PSNR metode vrlo se lako može uočiti na primjeru prikazanom na slici 3.



**Slika 3 a) originalna slika b ) Gaussov šum c) JPEG kompresija d) zamućenje [4]**

Prema gore navedenim slikama može se prikazati nepouzdanost PSNR ocijene kvalitete. Iznos srednje kvadratne pogreške MSE koja se koristi za krajnji rezultat PSNR vrijednosti jednak je za sve ispitivane slike iako je subjektivni doživljaj kvalitete različiti. No, ipak PSNR se ovisno o raspodjeli pogreške u rekonstruiranoj slici, može veoma razlikovati od subjektivne ocjene slike. Ako se radi o neprimjetnom prostornom pomaku sadržaja slike PSNR daje lošu objektivnu ocjenu, a subjektivni dojam je dobar. Ukoliko je pak velika pogreška sabrana u malo područje slike subjektivni dojam je loš, a PSNR daje dobru objektivnu ocjenu. Stoga je PSNR pogodno rabiti pri usporedbi različitih kompresijskih postupaka na istoj ispitnoj slici.

### **2.2.2 SSIM - *Structural Similarity Index***

*Structural Similarity Index*, tj. SSIM je metoda za mjerenje sličnosti između dvije slike. SSIM metoda je napravljena kako bi se poboljšale tradicionalne metode kvalitete slike kao što su PSNR i MSE. Glavni zadatak ove metode je da se što više približi ljudskoj

precepciji [2]. Ova metoda kreće od hipoteze da se ljudski vid može prilagoditi izvlačenju informacija iz vizualnih slika [5].

Zavisnost između piksela je veća što su oni međusobno bliži i to je informacija koja opisuje strukturu objekta na slici. Rezultati se dobiju preko tri lokalna prozora veličine (8x8). Ti prozori podijeljeni su na svjetlost, kontrast i strukturu. Rezultati se povezuju u jedan prozor i konačni rezultat je SSIM indeks.

SSIM je postupak koji se temelji na strukturalnim sličnostima, a dobiveni rezultati su u velikoj suglasnosti sa subjektivnim ocjenama kvalitetslikovnog sadržaja [9]. Ovaj postupak iskorištava svojstvo ljudskog vizualnog sustava koje je osjetljivo na izobličenja strukturalne informacije te promjene vezane uz kontrast i svjetlinu nastale unutar vizualnog sadržaja. Mjerenjem izobličenja svjetline i kontrasta dobiva se ocjena sa kvalitetu slikovnog sadržaja. Kvaliteta se izražava preko SSIM indeksa kvalitete, a računa se usporedbom originalne i ispitivane slike i to za svaki element će se dobiti slika/mapa SSIM indeksa[4]. Nakon računanja parametra svjetline  $l(x,y)$  između elemenata originalne i izobličene slike prema relaciji:

$$l(x,y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1} \quad (5)$$

i parametra kontrasta prema relaciji :

$$c(x,y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2} \quad (6)$$

te parametra strukturalne informacije prema relaciji :

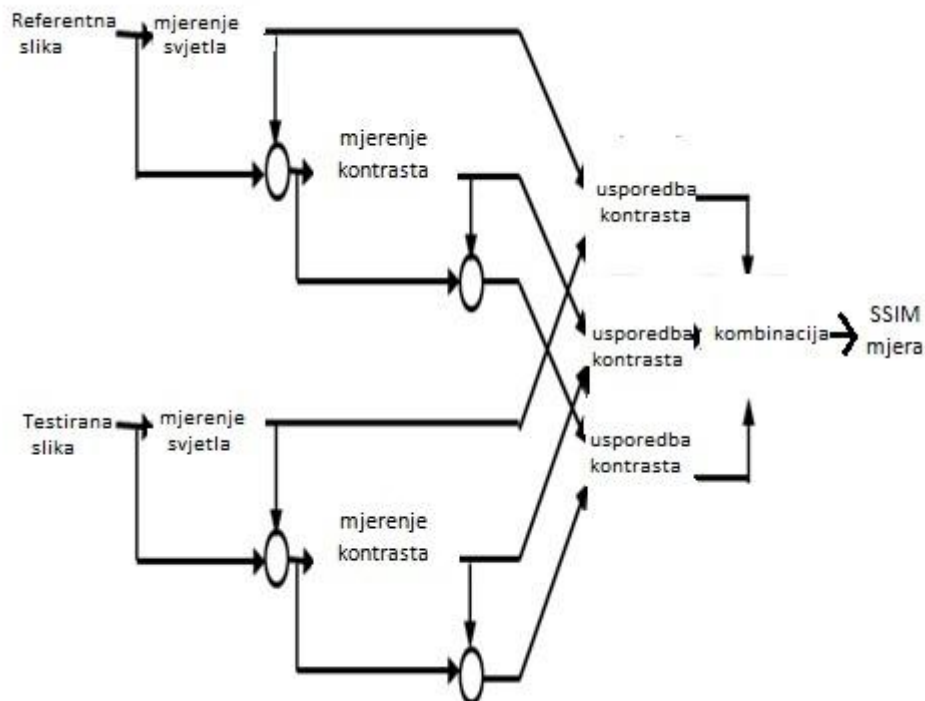
$$s(x,y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3} \quad (7)$$

moguće je izračunati SSIM indeks kao produkt ova tri parametra prema sljedećoj relaciji:



$$\text{SSIM}(\mathbf{x}, \mathbf{y}) = \frac{1}{C1} \frac{2\mu_x \mu_y + C2}{\sigma_x^2 + \sigma_y^2 + C2} \frac{2\sigma_{xy} + C3}{\sigma_x^2 + \sigma_y^2 + C3} \quad (8)$$

gdje  $\mu_x$  i  $\mu_y$  predstavljaju srednje vrijednosti  $X$  i  $Y$ ,  $\sigma_x$  i  $\sigma_y$  su standardne devijacije originalnog i rekonstruiranog signala dok je  $\sigma_{xy}$  iznos kovarijance za obje slike.  $C1$ ,  $C2$ ,  $C3$  su konstante dodane u relaciju kako bi se spriječilo dijeljenje s nulom.



**Slika 4 Blok dijagram SSIM algoritma**

Gornji dijagram pokazuje kako metoda radi. Referentna slika u odnosu na testiranu sliku gledamo kao kvalitetniji signal. Samim time testiranu sliku gledamo kao lošiji signal. Uz te pretpostavke mjerni sustav radi sličnosti signala uspoređujući strukturu, svjetlinu i kontrast. Kombiniranjem te tri stavke dobivamo konačni rezultat, a to je SSIM mjera[11]. Ukoliko je rezultat 1 neće postojati razlika između referentne i testirane slike.

### **2.2.3 Prednosti i mane PSNR i SSIM**

Eksperimentalnim dijelom prikazujemo usporedbu SSIM i PSNR rezultata, očekujemo da će i jedna i druga metoda pokazati približno iste rezultate ovisno o vrstama transformacija kojima smo djelovali na vizualni sadržaj. Na internacionalnoj konferenciji u Kanadi došli su do zanimljivih rezultata da rezultat dobiveni PSNR metodom osjetljiviji na Gaussov šum od SSIM metode. Dok SSIM metoda je osjetljivija na JPEG kompresije [12].

Također, ispitivanja vezana za Gaussovo zamućenje i JPEG2000 pokazala su slične rezultate za obje metode ali da su obje metode osjetljivije na Gaussov šum u odnosu na zamućenje. Ista stvar je i sa JPEG kompresijom i JPEG2000 kompresijom. Prednosti ove dvije metode su što se može iz PSNR metode zaključiti rezultatu SSIM metode i isto vrijedi obrnuto. Mana tih metoda je što se razlikuju po osjetljivosti ovisno o nekim transformacijama kojima djelujemo na vizualni sadržaj.

## **2.3 MANIPULACIJE NA SLIKAMA**

U današnje vrijeme slike se koriste kao izvor informacija te svakim djelovanjem na sliku moguće je kvalitetu slike promijeniti u odnosu na original. Na vizualni sadržaj djelovat ćemo sljedećim manipulacijama:


- JPEG kompresija
- Šumovi
- Gaussov filter
- Geometrijske transformacije

### **2.3.1 JPEG kompresija**

JPEG je najpopularniji format za prijenos slika na Internetu. Skoro svi digitalni fotoaparati i programi za obradu slika imaju mogućnost kreiranja JPEG datoteke [14].

JPEG (*Joint Photographic Expert Group*) format će se koristiti za fotografije i slike nježnijih tonova i boja, tj. za realistične scene.

JPEG format nam služi kako bi se smanjila veličina slike fotografskog tipa. Samim time nam je olakšan prijenos informacija pri korištenju u svakodnevnim aplikacijama. JPEG nam omogućava ovaj tip formata kao dobar kompromis između kvalitete slike i veličine datoteke.



a)

b)

**Slika 5 JPEG kompresija a) original b) JPEG kompresija**

### **2.3.2 Šumovi**


Šum predstavlja slučajne svjetline ili boje u slici koje su nastale u senzoru ili elektroničkom sklopu digitalne kamere ili skenera. Opisujemo ga kao slučajnu varijablu sa svojom srednjom vrijednosti, varijacijom i standardnom devijacijom. Podijeliti ćemo da u tri skupine [14]:

Fotoelektronički -termalni, fotonski

Impulsni - salt and pepper

Strukturirani - periodični, neperiodični

Nosie filter koji smo mi koristi u svojim mjerenjima sastoji se od 5 filtera. Koriste se za pripremu štampe, a može se koristiti i za uklanjanje šumova sa slike. Filtri iz ove grupe su : Add noise koji služi za dodavanje teksture koja izgleda kao prašina na slici. Osim toga može se i upotrebljavati i za korištenje retuša na slici. Despackle je filter za uklanjanje šuma na slici. Taj šum nastaje prilikom skeniranja slike. Medijan je filter koji spajajući i izjednačavajući svjetlost piksela s okolinom će reducirati šumove na vizualnom sadržaju.



a)

b)

**Slika 6 Šum a) Original b) Šum 25 % s horizontalnim zrcaljenjem**

### **2.3.3 Gaussov filter**

Gaussov filter ili Gaussov blur je filter koji se koristi za stvaranje sjene na slici te pri korištenju *anti-aliasa* na rubovima. Također ga možemo upotrijebiti kako bismo smanjili razliku između susjednih pikselima te nam pomaže nam da uklonimo zrnatost. Blur filteri osim što smanjuju razliku boja između susjednih piksela, mogu se koristiti i za specijalne efekte. Gaussov filter je samo jedan od 11 filtera koji nam koriste za oblikovanje slika. Jedna od poznatijih je i sam blur koji stvara gotovo neprimjetno zamagljivanje te time uklanja dijelove sa slike koji su preoštri. Jedan od vrste blura je motion blur kojim zamagljujemo sliku pa slika izgleda kao da je fotoaparatom i samim time se stvara iluzija kretanja na slici. Svim filterima je jedno zajedničko, a to je da vrše zamagljenje na slikama.



a)

b)

**Slika 7 Gaussov filter a) original b) Filter radiusa 4 piksela s horizontalnim zrcaljenjem**

#### **2.3.4 Geometrijske transformacije**

Kako bismo premjestili, rotirali, promijenili veličinu ili zrcalili vizualni sadržaj, to su operacije koje nazivamo geometrijskim transformacija.

Geometrijske transformacije mogu se koristiti na objektima prilikom modeliranja ali i za prikazivanje slika na izlaznom uređaju. Na izlaznom uređaju mijenjamo opis prozora koji se nalazi na koordinatama te samim time nam prikazuje sliku na izlaznom uređaju. Geometrijske transformacije se primjenjuju na objektima tokom modeliranja, kao i u proceduri za prikazivanje slike na izlaznom uređaju, gdje preoblikujemo opis prizora koji se nalazi u svjetskim koordinatama, omogućavajući tako prikaz na izlaznom uređaju.



a)

b)

c)

**Slika 8 Geometrijske transformacije a) original b) rotacija 90° c) zrcaljenje horizontalno**

### 3. EKSPERIMENTALNI DIO

#### 3.1. Postupak izvođenja eksperimentalnog dijela

U ovom radu uspoređujemo dobivene vrijednosti na vizualnom sadržaju na koji smo djelovali različitim manipulacijama s originalnim vizualnim sadržajem. Kako bismo mogli uspoređivati rezultate te donijeti kvalitetne zaključke slike koje smo odabrali iz testnog kataloga se razlikuju po sadržaju i boji. Za mjerenja ćemo koristiti portrete, mrtvu prirodu, pejzaže i životinje. Slike su u boji osim pejzaža koji je crno bijeli.


Kao što smo naveli gore u tekstu na slike ćemo djelovati Gaussovim filtrom, JPEG kompresijom, geometrijskim transformacijama kao što su rotacija i zrcaljenje te ćemo koristiti šum.

Prilikom djelovanja manipulacija na nekim slikama je vidljiva razlika dok na nekim je slika jednaka originalu. Pregledom slika ljudsko oko ne percipira razlike kod nekih slika, odnosno reklo bi se kako je kvaliteta ista između testirane slike i originala. No, rezultati su pokazali drugačije. Djelovanjem na slike manipulacijama kvaliteta slike kod nekih je drastično pala dok neke su skoro pa zadržale kvalitetu sličnu originalu.

Izdvojiti ćemo jednu kombinaciju slika u koloru kako bismo prikazali o kakvim manipulacijama je riječ te ove slike ćemo objasniti u dijelu rezultat.



a)




b)





c)



d)




e)



f)

**Slika 9 a)original; b) Gaussov filter radius 4 piksela; c) rotacija 90 stupnjeva; d) zrcaljenje horizontalno; e) JPEG komresija; f) Šum 25%**

Crno bijelu sliku izdvajamo kao usporedbu sa slikama u koloru.




a)




b)







c)



d)



e)



f)

**Slika 10 a)original b) Gaussov filter radius 4 piksela; c) rotacija 90 stupnjeva ; d) zrcaljenje horizontalno ; e) JPEG komresija; f) Šum 25%**

Sve slike na koje smo upotrijebili manipulacije smo proveli kroz programsko okruženje "Matlab". Pomoću logaritma koje smo gore naveli dobili smo rezultate.

### 3.2.Rezultati mjerenja i rasprava

**Tablica 1 PSNR i SSIM rezultati**

<b>PSNR I SSIM METODA</b>										
	<b>Radius 4 piksela</b>		<b>JPEG kompresija</b>		<b>Zrcaljenje horizontalno</b>		<b>Rotacija 90</b>		<b>Šum 25%</b>	
	<b>PSNR</b>	<b>SSIM</b>	<b>PSNR</b>	<b>SSIM</b>	<b>PSNR</b>	<b>SSIM</b>	<b>PSNR</b>	<b>SSIM</b>	<b>PSNR</b>	<b>SSIM</b>
<b>Lena</b>	24,86	0,765	45,79	0,998	11,75	0,265	11,52	0,253	17,01	0,451
<b>Leptir</b>	21,59	0,781	48,22	0,998	12,62	0,248	9,19	0,140	16,95	0,478
<b>Planina</b>	16,16	0,503	53,48	0,999	7,948	0,115	6,33	0,047	17,53	0,712
<b>Paprika</b>	23,83	0,795	45,87	0,998	10,59	0,244	9,95	0,219	17,03	0,442

Prema slikama koje smo dobili nakon manipulacija slika 9 pod b) i f) se najlošije vide , samim time bi se reklo da u odnosu na original njihova kvaliteta je puno slabija. Ostale slike se jasno vide i identične su originalu.

Sliku pod imenom Leptir smo uzeli za primjer te smo ju zacrvenili u tablici 1 s rezultatima. Ljudsko oko nam govori kako slika 9 b) i f) na koje smo djelovali Gaussovim filterom i šumom 25% imaju zamućenja. Prema rezultatima te dvije manipulacije skupa s JPEG kompresijom daje velike vrijednosti SSIM i PSNR. Dok slike na koje smo djelovali geometrijskim transformacijama i ni u kojem slučaju nismo utjecali na izgled slike imaju najmanje SSIM i PSNR vrijednosti. Da li samo oko može objektivno odlučivati o kvaliteti vizualnog sadržaja? Prema rezultatima koje smo dobili nemože. Ljudsko oko u usporedbi s algoritmima daje različite rezultate te se bolje osvrnuti na objektivne matematičke metode za odlučivanje kvaliteta slika.

Kao i kod slika u koloru slika 10 b) i slika f) imaju najveća zamućenja te samim time bi se reklo kako te slike imaju najlošiju kvalitetu u odnosu na ostale slike i original. Da li nas i tu oko vara? Rezultati su:

Slika koja je navedena gore je Planina te je označeno crveno u tablici 1. Kao i u koloru slike na koje smo djelovali Gaussovim filterom, JPEG kompresijom i šumom imaju puno veću kvalitetu od ostalih slika koje na prvi pogled izgledaju kao original. U ovom slučaju ljudsko oko ne prepoznaje nikakvu razliku osim da je izmjenjena slika rotirana, stoga obje metode ovdje daju krivi rezultat, jer ljudsko oko nije uočilo promijene u boji, teksturi, kvaliteti i rubovima.

Kao što smo naveli u teorijskom dijelu PSNR metoda može prikazati pobliže kakve rezultate će dati SSIM metoda i obratno. Kod SSIM metode ulaze tri parametra kod računanja kvalitete slika. Tako da za SSIM metodu izvoditi ćemo crno bijelu sliku jer odstupa sa svojim rezultatima puno više od slika u koloru. Slike u koloru zbog svojih rezultata koji su poprilično isti kao i kod PSNR metode ćemo samo prikazati u tablici. Crno bijela slika i kod PSNR metode i kod SSIM metode daje najlošije rezultate.

### **3.3.Usporedba PSNR i SSIM rezultata**

Kao što je rečeno u SSIM metodi ukoliko slika teži 1 to testirana slika teži originalu. Kod PSNR metode rezultati koji teže 100 decibela testirana slika će biti sličnija

originalu. Prema rezultatima koje smo dobili JPEG kompresija kod SSIM metode jedina teži 1, odnosno slike koje smo koristiti su najslabije originalu. Samim time rezultati koji su dobiveni u Kanadi da je SSIM metoda osjetljivija na JEG kompresiju je dokazana. Također, usporedbom rezultata SSIM metoda daje bolje rezultate od PSNR metode, ali uspoređujući ih možemo reći da te dve metode će na kraju ipak dati slične rezultate te se možemo pouzdati u njih.

Osim toga, prilikom korištenja te dvije mjere slike se moraju dijeliti u dvije grupe kako bi se uspoređivale. Prva grupa je slike u koloru, dok druga druga crno bijele slike. Razlog toga je što prema dobivenim rezultatima crno bijele slike su puno manje kvalitete nakon manipulacije nego slike u koloru.

Također, pregledom slika efekt zamućenja i šuma neće toliko uništiti kvalitetu slike kao što bi mnogi rekli tj. ljudsko oko neće tu promijenu zapaziti, već transformaciju koju vrlo rado svi koristimo a to su zrcaljenje ili rotacija po kvaliteti skoro pa nisu iste slike.

Analizom rezultata obje metode ustvrdili smo da se rezultati podudaraju, tj. ukoliko je za neku sliku po jednoj mjeri smanjena kvaliteta, isto takve rezultate će dati i druga mjera.

## 4. ZAKLJUČAK

Nakon dobivenih rezultata ljudska percepcija ne može biti ni približno slična objektivnim metodama. Objektivne metode algoritmima i dodanim stavkama jasno mogu reći koja slika je bolje kvalitete jer nas oko može često prevariti.

Usporedbom rezultata crno bijele slike daju puno lošije rezultate od slika u koloru iako su i na jedne i na druge slike korištene iste manipulacije.

Eksperimentom je potvrđena pretpostavka kako su PSNR i SSIM metoda po svojim rezultatima slične te unaprijed možemo predvidjeti rezultate jedne metode ukoliko je druga izračunata.

Da li je SSIM metoda bolje ili lošija od PSNR metode? SSIM metoda je, zbog svoja tri parametra koja se prvo moraju izračunati (kontrast, struktura i svjetlina) te nakon toga ujediniti, kompleksnija i konkretnija metoda. Zbog svih parametara rezultat je objektivniji i jasno daje do znanja koja slika je kvalitetnija u odnosu na original. PSNR metoda zbog svog MSE koji je isti za sve slike bez obzira na manipulacije ne daje toliko točne rezultate kao i SSIM metoda.

Prilikom uporabe manipulacija na vizualni sadržaj svakako će kvaliteta tog sadržaja padati. Podaci sadržaja se gube i ne može se cijeli sadržaj sačuvati. No, ukoliko je potrebno sačuvati kvalitetu JPEG kompresija će sačuvati što je više moguće informacija tako da sadržaj bude što sličniji ako ne i isti originalu. Također, efekti zamućenja neće toliko uništiti sliku kao najjednostavnije manipulacije, koje vrlo rado svi koristimo, a to su zrcaljenje i rotacije jer kod tih promijena promatrač neće primjetiti promijenu kvalitete.

## 5. LITERATURA

- [1] Emil Dumić. "Postupci za objektivnu ocjenu kvalitete slike". [On-line]. Available: [https://www.fer.unizg.hr/\\_download/repository/Dumic,\\_KDI.pdf](https://www.fer.unizg.hr/_download/repository/Dumic,_KDI.pdf)
- [2] Bojan Perić. "Master rad - Poređenje MPEG-2 i MPEG-4 standarda", [On-line]. Available: <http://static.elitesecurity.org/uploads/3/1/3197673/MasterTestovi.pdf>
- [3] \*\*\* [http://en.wikipedia.org/wiki/Peak\\_signal-to-noise\\_ratio](http://en.wikipedia.org/wiki/Peak_signal-to-noise_ratio), *Wikipedia, Peak signal-to-noise ratio*, 02.09.2015.
- [4] Goran Gvozden. "Uporaba značajki vizualnog sadržaja za objektivno vrednovanje kvalitete slike". [Online]. Available: [https://www.fer.unizg.hr/\\_download/repository/Goran\\_Gvozden,\\_KDI.pdf](https://www.fer.unizg.hr/_download/repository/Goran_Gvozden,_KDI.pdf)
- [5] D. Dragan. "Metrika prihvatljivosti kompresione tehnike mirne slike u implementaciji pacs sistema" doktorska disertacija, Univerzitet u Novom sadu fakultet tehničkih nauka, Novi sad, 2013.
- [6] \*\*\* <http://www.vcl.fer.hr/dtv/jpeg/ocjena.htm>, Mihael Jančić, 2.9.015.
- [7] Sanja Maksimović-Moićević. "predlog nove mere za ocenu kvaliteta slike prilikom interpolacije i njena implementacija u računarskoj obradi signal slike", doktorska disertacija, Univerzitet u Novom sadu Fakultet tehničkih nauka odsek za računarsku tehniku i računarske komunikacije, Novi sad, 2015.
- [8] Eskicioglu A.M.: „Quality measurement for monochrome compressed images in the past 25 years“, Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing – 2000, Vol.4, pp.1907-1910, 2000.
- [9] Wang Z., et al: „Image quality assessment: from error visibility to structural similarity“, IEEE Transactions on Image Processing, Vol.13, No.4, pp.600-612, 2004.

[10] Carnec M., Le Callet P., and Barba D.: „Objective quality assessment of color images based on a generic perceptual reduced reference,“ Signal Processing: Image Communication, Vol.23, No.4, pp.239-256, 2008.

[11] Petra Rožman. "SSIM – structural similarity index/ measurement system", Teorija rastriranja, 21.11.2014., [On-line] Available:  
[http://www.igt.si/tadejamuck/files/2012/12/SSIM\\_rozman.pdf](http://www.igt.si/tadejamuck/files/2012/12/SSIM_rozman.pdf)

[12] A. Horé, D. Ziou. (2010). “ Image quality metrics: PSNR vs. SSIM.” Proceedings - International Conference on Pattern Recognition. [Online]. Available:  
[http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=5596999&queryText=psnr+vs+ssim&newsearch=true&searchField=Search\\_All](http://ieeexplore.ieee.org/xpl/articleDetails.jsp?arnumber=5596999&queryText=psnr+vs+ssim&newsearch=true&searchField=Search_All).

[13] I. Andabak, I. Gaura (2010), Utjecaj kompresije na kvalitetu slike, seminarski rad, Grafički fakultet, Zagreb

[14] R. A. Schowengerdt, "Image Noise" [Online], Available:  
<http://www.dig.cs.gc.cuny.edu/seminars/IPC/pres12.pdf> [Accessed: Sept., 2009]

[15] Vedran Furač. " Uklanjanje šuma iz slike korištenjem dvodimenzionalne metode relativnog presjecišta intervala pouzdanosti", [On-line] ]. Available:  
[http://vedranf.net/d/dipl\\_vedranf.pdf](http://vedranf.net/d/dipl_vedranf.pdf), Rijeka, 2009.

[16] Samir Kovačić. " Photoshop filters", SEMINARSKI RAD, Univerzitet u Zenici pedagoški fakultet U Zenici osjek: matematika i informatika, Zenica, April 2007. GODINE, [On-line] ]. Available:  
<http://www.am.unze.ba/cdp/pdf/KovacicSamir%20Filteri.pdf>

[17]\*\*\* <https://homepages.cae.wisc.edu/~ece533/images/>, 14.8.2015.